

Jan **MACHNIEWSKI**  
Benedykt **NOWAK**

Instytut Elektroniki  
Politechniki Śląskiej

## ZASTOSOWANIE ALGORYTMÓW GENETYCZNYCH DO PROJEKTOWANIA UKŁADÓW ANALOGOWYCH

**Streszczenie.** W pracy przedstawiono nowe, heurystyczne podejście do projektowania pewnej klasy układów analogowych. Przydatność do tych celów algorytmów genetycznych została pokazana na przykładzie projektowania filtra. W końcowej części pokazano wpływ doboru parametrów algorytmu genetycznego na jakość uzyskiwanych rozwiązań.

### GENETICS ALGORITHMS FOR ANALOG CIRCUITS DESIGN

**Summary.** The paper presents the new, heuristic idea of designing analog circuits. On the basis of an example of a filter there has been shown the usefulness of the genetic algorithms in electronics. At the end there has been discussed influence of GA's parameters on the solution

### DIE VERWENDUNG DER GENETISCHEN ALLGORITHMUSE ZUR PROJEKTIERUNG DER ELEKTRONISCHEN ANALOGSCHALTUNGEN

**Zusammenfassung.** Im Aufsatz wurde die neue heuristische Einstellung zur Projektierung der Anlogschaltung vorstellt. Die Brauchbarkeit zu diesen zwecke der genetischen Algorithmuse wurde am Beispiel der Projektierung des Filters gezeigt. Zum Schluß wurde der Einfluß der Wahl der Parametere der genetischen Algorithme auf die Qualität der erreichten Lösungen gewiesen.


## 1. Wprowadzenie

Podczas projektowania układów analogowych, takich jak np. filtry, nie istnieje jedna, najlepsza metoda doboru wartości elementów. Kluczowym zagadnieniem przy projektowaniu tego typu układów jest optymalizacja, dokonywana najczęściej za

pomocą metod numerycznych [4], nierzadko heurystycznych. Algorytmy genetyczne (AG) są jeszcze jedną próbą podejścia do tego problemu.

## 2. Algorytmy genetyczne


AG należą do grupy metod heurystycznych i wzorują się na metodzie doboru naturalnego występującego w przyrodzie [1, 2, 3]. Jednym z podstawowych pojęć jest kod genetyczny. **Kod genetyczny** jest to łańcuch złożony z zer i jedynek (lub większej liczby liter zdefiniowanych dla danego problemu) jednoznacznie opisujący dany organizm. I tak w przypadku układu analogowego kolejne części łańcucha genetycznego mogą opisywać wartości elementów układu, zakładając, że struktura układu jest znana.



Rys. 1. Kod genetyczny reprezentujący układ analogowy

Fig. 1. The genetic code representing an analog circuit

Jeśli wyróżnimy dwie wartości elementu reprezentujące zwarcie i rozwarcie, to będziemy mogli również modyfikować strukturę, choć tylko w kierunku od struktury bardziej rozbudowanej do prostszej, posiadającej jednak zadane własności.



Rys. 2. Ilustracja krzyżowania dwupunktowego

Fig. 2. Two-point crossover

Ewolucyjne polepszanie osobników jest możliwe dzięki kombinacji trzech operacji: krzyżowania, mutacji i selekcji. **Krzyżowanie** jest podstawowym mechanizmem zapewniającym polepszanie populacji. Polepszanie to jest możliwe dzięki wymianie materiału genetycznego. Wymiana odbywa się poprzez podział łańcuchów dwóch osobników w tym samym punkcie (lub w większej liczbie punktów) i utworzenia nowych łańcuchów składających się z części łańcucha A oraz B.

Nowo utworzone osobniki każdorazowo są oceniane. Osobniki najlepiej przystosowane (posiadające najwyższe oceny) mają najwięcej szans na rozmnożenie się i tym samym utrwalenie swojego kodu w populacji. Osobniki posiadające średnie oceny mają znacznie mniejsze szanse na rozmnożenie się, a osobniki najłabsze giną - są usuwane z populacji. W ten sposób w populacji dokonuje się **selekcja**.

<i>n</i> - ta populacja				
A	A1	A2	A3	0.8
B	B1	B2	B3	0.8
C	C1		C2	0.7
D	D1	D2	D3	0.6
E	E			0.5
F	F1	F2	F3	0.4
G	G			0.3
H	H1		H2	0.3
I	I			0.2
J	J			0.1

<i>n+1</i> - populacja				
AB	A1	B2	A3	0.85
A	A			0.8
B	B			0.8
C	C			0.7
D	D			0.6
BA	B1	A2	B3	0.57
E	E			0.5
F	F			0.4
CH	C1		H2	0.36
FD	F1	D2	F3	0.32

Rys. 3. Ilustracja zmian zachodzących w populacji na skutek operacji krzyżowania i selekcji  
Fig. 3. Modification of a population by crossover and selection

Pewnym ryzykiem jest grupowanie łańcuchów wokół ekstremów lokalnych uniemożliwiające - z braku materiału genetycznego - znalezienie lepszego rozwiązania. Zabezpieczeniem przed taką ewentualnością jest mutacja. **Mutacja** polega na przypadkowych, niewielkich zmianach w kodzie genetycznym, przerzucając rozwiązania w nowe obszary i zabezpieczając w ten sposób populację przed utknięciem w lokalnym ekstremum.

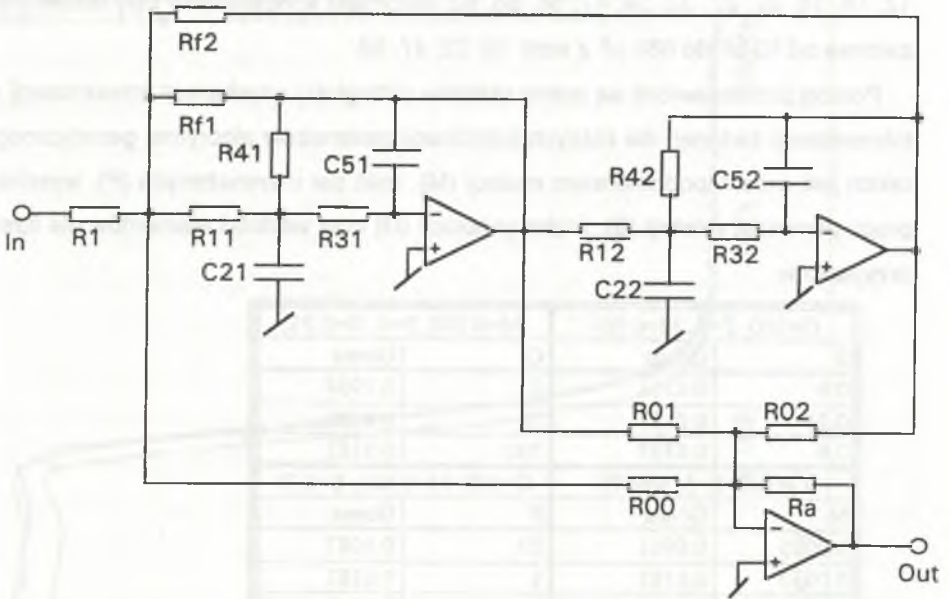
Do tej pory algorytmy genetyczne doczekały się licznych zastosowań w wielu dziedzinach [1], takich jak: fizyka, nauki społeczne, przetwarzanie i rozpoznawanie obrazów, biologia, oraz wielu zastosowań inżynierskich.

### 2.1. Czym algorytmy genetyczne różnią się od tradycyjnych metod optymalizacji?

- \* Algorytmy genetyczne operują parametrami nie bezpośrednio, ale w postaci zakodowanej. Dzięki tej własności można zestawiać obok siebie parametry różnego typu, bez konieczności wprowadzania zmian do zasadniczej części programu realizującej algorytm genetyczny.
- \* Algorytm genetyczny operuje nie pojedynczym punktem, ale zbiorem punktów przeszukiwanej przestrzeni.
- \* Algorytm genetyczny nie stawia żadnych wymagań odnośnie do postaci optymalizowanej funkcji, jedynie musimy umieć ocenić otrzymane rozwiązanie. Np. nie jest wymagane, aby funkcja była różniczkowalna.
- \* Działanie operatorów jest czysto stochastyczne, nie jest w żaden sposób zdeterminowane.

### 3. Przykład

Poniżej przedstawiony zostanie przykład projektowania filtra dolnoprzepustowego spełniającego następujące kryteria  $K(0) = 1$  i  $w_0 = 1000$ . W przykładzie wykorzystano typową strukturę [4] przedstawioną na rysunku poniżej. Ta sama struktura została wykorzystana w naszej pierwszej pracy poświęconej zastosowaniu algorytmów genetycznych w elektronice. Ponieważ otrzymane wtedy rezultaty okazały się interesujące, postanowiliśmy kontynuować temat.



Rys. 4. Filtr dolnoprzepustowy  
 Fig. 4. The low-pass filter

Znając strukturę filtru możemy wyliczać jego transmitancję jako funkcję częstotliwości i wartości elementów  $K(\omega, R_1, R_2, \dots, R_n, C_1, C_2, \dots, C_m)$  i porównywać z zadaną transmitancją. W prezentowanym przykładzie transmitancja była porównywana w 9 punktach, dla następujących pulsacji:  $\omega_1 = 0$ ,  $\omega_2 = 100$ ,  $\omega_3 = 200$ ,  $\omega_4 = 500$ ,  $\omega_5 = 1000$ ,  $\omega_6 = 2000$ ,  $\omega_7 = 5000$ ,  $\omega_8 = 10\,000$  i  $\omega_9 = 100\,000$ .

W tym przykładzie dobór wartości elementów jest w całości dokonany przez algorytm genetyczny bez korzystania jakichkolwiek wskazówek wynikających z teorii i znanych metod projektowania filtrów, aby uniknąć wątpliwości, co jest zasługą algorytmu genetycznego, a co metod tradycyjnych. Jednakże w aplikacjach praktycznych należałoby wykorzystywać wszelkie informacje pozwalające ograniczyć przestrzeń projektową.

Rezystory były dobierane z zakresu od 10  $\Omega$  do 8,2 M $\Omega$  z następującej serii: 10, 12, 15, 18, 22, 27, 33, 39, 47, 56, 68, 82, natomiast kondensatory były dobierane z zakresu od 10 pF do 680  $\mu$ F z serii: 10, 22, 47, 68.


Poniżej przedstawione są oceny układów (odległości uzyskanych transmitancji od transmitancji zadanej) dla różnych kombinacji parametrów algorytmu genetycznego, takich jak: prawdopodobieństwo mutacji (M), ilość par rozmnażanych (P), wysokość progu pierwszej selekcji (S), liczba generacji (G) oraz wartości elementów dla trzech przypadków.

G=300, P=5, M=0.001		M=0.001, P=5, S=0.75,	
S	Ocena	G	Ocena
0.9	0.0311	0	0.1964
0.75	0.0183	50	0.0928
0.6	0.0397	300	0.0183
G=300, P=5, S=0.75		G=300, M=0.001, S=0.75	
M	Ocena	P	Ocena
0.0005	0.0911	20	0.1087
0.0010	0.0183	5	0.0183
0.0033	0.0556	2	0.1026

Rys. 5. Oceny rozwiązań dla różnych kombinacji parametrów  
Fig. 5. Fitness function for various value of parameters

R[ $\Omega$ ],C[F]	próg=0.9	próg=0.75	próg=0.6
R1	2200	180k	6800
R11	33	39	180
R31	330	560k	820
R41	2200	18k	22k
C21	100 000n	1000n	6 800n
C51	4700p	47p	68n
R12	22	270	120
R32	82k	3300	560
R42	8.2M	12k	3.9M
C22	68n	47 000n	680n
C52	680p	47p	22n
Rf1	220	12k	8.2M
Rf2	390	3900	390
R00	3.9M	47	8.2M
R01	3.9M	56k	56k
R02	680	33	2700
Ra	3900	1500	47k

Rys. 6. Wartości elementów dla przypadku G=300, M=0,001, P=5  
Fig. 6. Elements value for G=300, M=0,001, P=5



Rys. 7. Rezultaty symulacji dla  $G = 300$ ,  $P = 5$ ,  $M = 0,001$   
Fig. 7. Simulations results for  $G = 300$ ,  $P = 5$ ,  $M = 0,001$

#### 4. Wnioski

Przeprowadzony eksperyment wykazał, że algorytmy genetyczne mogą być użyteczne przy projektowaniu układów analogowych. Szczególnie w przypadkach, gdy trzeba spełnić różnorakie, powiązane ze sobą wymagania. Na szczególną uwagę zasługuje możliwość zestawiania różnych wymagań, bez konieczności dokonywania zmian w zasadniczym algorytmie. Zmiany ograniczają się w takim przypadku do skonstruowania nowej funkcji oceniającej, co nie jest ani trudne, ani czasochłonne.

Jak wykazał przeprowadzony eksperyment, zależność między parametrami algorytmu genetycznego a jakością uzyskanego rozwiązania nie jest prosta. Nie można poprzez proste zwiększanie wartości tych parametrów uzyskiwać coraz to lepszych wyników. Istnieje pewne optimum, dla którego szybko uzyskuje się dobre rozwiązanie. Dotychczasowe doświadczenia wskazują, że liczba par rozmnażanych powinna stanowić kilka-kilkanaście procent całej populacji, natomiast prawdopodobieństwo mutacji powinno być rzędu tysięcznych. Jednak na razie trudno jest od razu przewidzieć optymalny dobór wartości parametrów; wymaga to przeprowadzenia kilku eksperymentów.

#### LITERATURA

1. Goldberg D.E.: Genetic algorithms in search, optimization, and machine learning. Addison-Wesley, 1989.
2. Holland J.H., Holyoak K.J., Nisbett R.E., Thagard P.R.: Induction: processes of inference, learning, and discovery. Mit Press, 1986.
3. Holland J.H.: Adaptation in natural and artificial systems. Mit Press, 1992.
4. Temes G.C., Mitra S.K.: Modern filter theory and design. Warsaw 1978.
5. Machniewski J., Nowak B.: Application of genetic algorithms for designing and optimization of electronic circuits. XIV National Conference - Circuit Theory and Electronic Circuits, Kołobrzeg, Poland, Oct. 26-28, 1993.

Recenzent: Prof.dr hab.inż. Ryszard Tadeusiewicz

Wpłynęło do Redakcji 15.10.1994 r.



**Abstract**

The paper presents the new, heuristic idea of designing analog circuits. At the beginning the paper introduce the theory of genetic algorithms - search algorithms based on the mechanics of natural selection and genetics. Chapter 2 explain „what are genetic algorithms?” and „how are genetic algorithms different from traditional methods” and illustrate the operators of genetic algorithms.

On the basic of an example of a typical structure of a low-pass filter there has been shown how to use genetic algorithms in optimisation of electronic circuits. This is our original application of genetic algorithms.

There has been shown influence of genetic algorithm's parameters such:

- number of pair intercrossed,
- mutation probability,
- treshold of the first selection

on the solution.

At the end there has been presented the result of simulation by SPICE and value of elements generated by genetic algorithms.